

# Probabilistic graphical models: Assignment 3

Seung-Hoon Na

June 7, 2017

## 1 Gibbs sampler for Beta-Binomial

Binomial 및 beta 분포는 다음과 같이 정의된다.

- $k \sim \text{Bin}(n, \theta)$ : binomial distribution은 성공확률이  $\theta$ 인 시도에서,  $n$ 번 시행 중  $k$ 번 성공할 확률 분포로 을 따르는 랜덤 변수 (random variable)로 pmf (probability mass function)는 다음과 같다 <sup>1</sup>.

$$\text{Bin}(k|n, \theta) \triangleq \binom{n}{k} \theta^k (1 - \theta)^{n-k} \quad (1)$$

- $\theta \sim \text{Beta}(a, b)$ : Beta distribution는 도메인이 구간  $[0, 1]$ 인 분포로 다음과 같이 정의된다.

$$\text{Beta}(\theta|a, b) \triangleq \frac{1}{B(a, b)} \theta^{a-1} (1 - \theta)^{b-1} \quad (2)$$

여기서  $\theta$ 는 구간  $[0, 1]$ 에 속하는 원소이고,  $B(a, b)$ 는 beta함수로 다음과 같이 정의된다.

$$B(a, b) = \frac{\Gamma(a)\Gamma(b)}{\Gamma(a+b)} \quad (3)$$

Beta-binomial는 binomial 분포의 parameter  $\theta$ 에 대한 prior로 beta분포를 취하는 directed graphical model 모델로 sampling 과정은 다음과 같다.

$$\begin{aligned} \theta &\sim \text{Beta}(a, b) \\ k &\sim \text{Bin}(n, \theta) \end{aligned}$$

### 1.1 Joint distribution for Beta-Binomial

Beta-binomial의 joint distribution  $P(k, \theta|a, b, n) = \text{Beta}(\theta|a, b) \text{Bin}(n, \theta)$  을 간단히 정리하시오.

$$P(k, \theta|a, b, n) =$$

---

<sup>1</sup> $k$ 는 어느 랜덤 변수 (random variable)의 값이며, 단순화를 위해 랜덤 변수는 생략하였다. 보다 엄밀하게 random variable  $X$ 가 주어질때,  $X \sim \text{Bin}(n, \theta)$ 이면, 이에 대한 확률 분포는  $\text{Bin}(X = k|n, \theta)$ 로 표기된다.

## 1.2 Full conditionals for Beta-Binomial

위의  $P(k, \theta|a, b, n)$ 을 이용하여 Beta-Binomial의 full conditionals인  $P(\theta|k, a, b, n)$ 과  $P(k|\theta, a, b, n)$ 을 유도하시오.

$$\begin{aligned} P(\theta|k, a, b, n) &= \\ P(k|\theta, a, b, n) &= \end{aligned} \tag{4}$$

## 1.3 Gibbs sampling for Beta-Binomial

위의 full conditional distribution을 이용하여 marginal probability  $P(k|a, b, n) = \int_0^1 P(k|\theta, a, b, n)P(\theta|a, b, n)d\theta$ 를 근사화시키는 Gibbs sampling algorithm 을 작성하시오.

## 1.4 Exact inference: Margin probability for Beta-Binomial

$\theta$ 에 해당되는 variable을 제거하여  $P(k|a, b, n) = \int_0^1 P(k|\theta, a, b, n)P(\theta|a, b, n)d\theta$ 를 간략히 하시오.

## 1.5 Implementation: Gibbs sampling for Beta-Binomial (python code제출)

위에서 작성된 Gibbs sampling for Beta-Binomial을 python으로 구현하고 sample size를 500,  $n = 16$ 으로 놓고, 다음의  $a, b$ 에 대해서 Exact inference결과와 Gibbs sampling으로 approximation된 결과를 비교하는 histograms을 보이시오.

- $a = 2, b = 2$ 일때
- $a = 2, b = 5$ 일때
- $a = 1, b = 10$ 일때

## 2 Gibbs sampler for Dirichlet-Multinomial

Multinomial, Multinoulli, 및 Dirichlet분포는 다음과 같이 정의된다.

- $\mathbf{x} \sim \text{Mu}(n, \boldsymbol{\theta})$ :  $K$  color balls로 구성된 임의의 박스에서 <sup>2</sup>,  $\boldsymbol{\theta} = (\theta_1, \dots, \theta_K)$ 에서  $\theta_j$ 는  $j$ 번째 color ball를 추출할 확률을 의미할때, *multinomial distribution*은  $n$ 번의 시행 중,  $\mathbf{x} = (x_1, \dots, x_K)$ 에서  $x_j$ 는  $j$ 번째 color ball이 추출된 횟수로 다음과 같이 정의된다.

$$\text{Mu}(\mathbf{x}|n, \boldsymbol{\theta}) \triangleq \binom{n}{x_1 \dots x_K} \prod_{j=1}^K \theta_j^{x_j} \tag{5}$$

---

<sup>2</sup>  $K$ 는 ball의 color종류의 수이고 박스에 있는 공의 갯수는 unknown이라 가정한다.

- $\mathbf{x} \sim \text{Mu}(1, \boldsymbol{\theta})$ : Multinomial 분포에서  $n = 1$ 인 특수한 경우로 categorical 또는 discrete distribution이라고도 하고, 다음과 같이 정의된다.

$$\text{Cat}(\mathbf{x}|\boldsymbol{\theta}) = \text{Mu}(\mathbf{x}|1, \boldsymbol{\theta}) \triangleq \prod_{j=1}^K \theta_j^{x_j} \quad (6)$$

- $\boldsymbol{\theta} \sim \text{Dir}(\boldsymbol{\alpha})$ : 도메인이 probability simplex  $S_K = \left\{ \boldsymbol{\theta} \mid \sum_{k=1}^K x_k = 1, 0 \leq \theta_k \leq 1 \right\}$  일때 *Dirichlet distribution*은 다음과 같이 정의된다.

$$\text{Dir}(\boldsymbol{\theta}|\boldsymbol{\alpha}) \triangleq \frac{1}{B(\boldsymbol{\alpha})} \prod_{k=1}^K \theta_k^{\alpha_k - 1} \quad (7)$$

여기서  $B(\boldsymbol{\alpha})$ 는 벡터로 일반화된 beta함수로 다음과 같이 정의된다.

$$B(\boldsymbol{\alpha}) = \frac{\Gamma(\alpha_1) \cdots \Gamma(\alpha_K)}{\Gamma(\alpha_1 + \cdots + \alpha_K)} \quad (8)$$

Dirichlet-multinomial (또는 Dirichlet Compound Multinomial)는 multinomial 분포의 parameter인  $\boldsymbol{\theta}$ 에 대한 prior로 Dirichlet분포를 취하는 directed graphical model모델로 sampling 과정은 다음과 같다.

$$\begin{aligned} \boldsymbol{\theta} &\sim \text{Dir}(\boldsymbol{\alpha}) \\ \mathbf{x} &\sim \text{Mu}(n, \boldsymbol{\theta}) \end{aligned}$$

## 2.1 Joint distribution for Dirichlet-Multinomial

Dirichlet-Multinomial의 joint distribution  $P(\mathbf{x}, \boldsymbol{\theta}|\boldsymbol{\alpha}, n) = \text{Dir}(\boldsymbol{\theta}|\boldsymbol{\alpha})\text{Mu}(\mathbf{x}|n, \boldsymbol{\theta})$ 을 간단히 정리하시오.

$$P(\mathbf{x}, \boldsymbol{\theta}|\boldsymbol{\alpha}, n) =$$

## 2.2 Full conditionals for Dirichlet-Multinomial

위의  $P(\mathbf{x}, \boldsymbol{\theta}|\boldsymbol{\alpha}, n)$ 을 이용하여 Dirichlet-Multinomial의 full conditionals인  $P(\boldsymbol{\theta}|\mathbf{x}, \boldsymbol{\alpha}, n)$ 과  $P(\mathbf{x}|\boldsymbol{\theta}, n)$ 을 유도하시오.

$$\begin{aligned} P(\boldsymbol{\theta}|\mathbf{x}, \boldsymbol{\alpha}, n) &= \\ P(\mathbf{x}|\boldsymbol{\theta}, n) &= \end{aligned} \quad (9)$$

## 2.3 Gibbs sampling for Dirichlet-Multinomial

위의 full conditional distribution을 이용하여 marginal probability  $P(\mathbf{x}|\boldsymbol{\alpha}, n)$ 를 근사화시키는 Gibbs sampling algorithm 을 작성하시오 (block sampling을 이용).

## 2.4 Exact inference: Margin probability for Dirichlet-Multinomial

$\boldsymbol{\theta}$ 에 해당되는 variable을 제거하여  $P(\mathbf{x}|\boldsymbol{\alpha}, n)$ 에 대한 간략식을 유도하시오.

## 2.5 Implementation: Gibbs sampling for Dirichlet-Multinomial (python code제출)

위에서 작성된 Gibbs sampling for Dirichlet-Multinomial을 python으로 구현하고 sample size를 500,  $n = 16$ 으로 놓고, 다음의  $\alpha$ 에 대해서 Exact inference결과와 Gibbs sampling으로 approximation된 결과를 비교하시오.

- $K=3, \alpha = (3, 3, 5)$
- $K=3, \alpha = (3, 10, 5)$
- $K=5, \alpha = (3, 5, 5, 8, 10)$

## 3 Collapsed Gibbs sampler for Latent Dirichlet Allocation (LDA)




Figure 1: A graphical model for LDA

Figure 1은 LDA에 대한 graphical model로, 토픽의 갯수가  $K$ 이고,  $N_d$ 의 단어로 구성된 문서  $d$ 를 generation하는 과정은 다음과 같다<sup>3</sup>.

1. For  $i \in [1, \dots, K]$ :  $\phi_i \sim \text{Dir}(\beta)$  ( $i$ 번째 토픽에 대한 Multinoulli parameter를 생성한다.)
2.  $\theta \sim \text{Dir}(\alpha)$
3. For  $j \in [1, \dots, N_d]$ :
  - $z_j \sim \text{Cat}(\theta)$
  - $w_j \sim \text{Cat}(\phi_{z_j})$

표기를 간단히 하기 위해서,  $\Phi = (\phi_1, \dots, \phi_K)$ 로  $\Phi$ 를  $K$ -topic multinomial 파라미터로 사용하기로 한다.

주어진 문서  $d$ 에 대해, 단어열이  $w$ 로 주어지고, 이들 단어열에 대한 topic assignments가  $z$ , topic mixture parameter가  $\theta$ ,  $K$ -topic multinomial 파라미터  $\Phi$ 에 대한, LDA의 joint distribution은 다음과 같다.

<sup>3</sup>LDA에 대한 상세한 내용은 다음을 참고하시오.

Blei, David M.; Ng, Andrew Y.; Jordan, Michael I. Latent Dirichlet Allocation. Journal of Machine Learning Research. 3 (4-5): pp. 993–1022

$$\begin{aligned}
P(\mathbf{w}, \mathbf{z}, \boldsymbol{\theta}, \boldsymbol{\Phi} | \boldsymbol{\alpha}, \boldsymbol{\beta}) &= P(\mathbf{w}, \mathbf{z}, \boldsymbol{\theta}, \phi_1^K | \boldsymbol{\alpha}, \boldsymbol{\beta}) \\
&= \prod_{i=1}^K \text{Dir}(\phi_i | \boldsymbol{\beta}) \text{Dir}(\boldsymbol{\theta} | \boldsymbol{\alpha}) \prod_{j=1}^{N_d} \text{Cat}(z_j | \boldsymbol{\theta}) \text{Cat}(w_j | \phi_{z_j})
\end{aligned}$$

$M$ 개의 문서 전체 집합  $\mathcal{C}$ 에 대해 단어열이  $\mathbf{W} = \mathbf{w}_1 \cdots \mathbf{w}_M$ , topic assignments가  $\mathbf{Z} = \mathbf{z}_1 \cdots \mathbf{z}_M$ , topic mixture가  $\boldsymbol{\Theta} = \boldsymbol{\theta}_1 \cdots \boldsymbol{\theta}_M$ 일때,  $\mathcal{C}$ 에 대한 LDA의 joint distribution는 다음과 같다.

$$\begin{aligned}
P(\mathbf{W}, \mathbf{Z}, \boldsymbol{\Theta}, \boldsymbol{\Phi} | \boldsymbol{\alpha}, \boldsymbol{\beta}) &= P(\mathbf{w}, \mathbf{z}, \boldsymbol{\theta}_1^M, \phi_1^K | \boldsymbol{\alpha}, \boldsymbol{\beta}) \\
&= \prod_{i=1}^K \text{Dir}(\phi_i | \boldsymbol{\beta}) \prod_{j=1}^M \text{Dir}(\boldsymbol{\theta}_j | \boldsymbol{\alpha}) \prod_{k=1}^{N_{d_j}} \text{Cat}(z_{jk} | \boldsymbol{\theta}_j) \text{Cat}(w_{jk} | \phi_{z_{jk}})
\end{aligned}$$

### 3.1 Marginal distribution for Latent Dirichlet Allocation (LDA)

LDA의 joint probability에서  $\boldsymbol{\theta}, \boldsymbol{\Phi}$ 를 elimination하여 다음 marginal probability  $P(\mathbf{w}, \mathbf{z} | \boldsymbol{\alpha}, \boldsymbol{\beta})$ 을 간결히 정리하시오.

$$P(\mathbf{w}, \mathbf{z} | \boldsymbol{\alpha}, \boldsymbol{\beta}) = P(\mathbf{z} | \boldsymbol{\alpha}) P(\mathbf{w} | \mathbf{z}, \boldsymbol{\alpha}, \boldsymbol{\beta})$$

여기서  $P(\mathbf{z} | \boldsymbol{\alpha})$ 와  $P(\mathbf{w} | \mathbf{z}, \boldsymbol{\alpha}, \boldsymbol{\beta})$ 는 다음과 같이 정의된다.

$$\begin{aligned}
P(\mathbf{z} | \boldsymbol{\alpha}) &= \int P(\boldsymbol{\theta} | \boldsymbol{\alpha}) P(\mathbf{z} | \boldsymbol{\theta}) d\boldsymbol{\theta} \\
P(\mathbf{w} | \mathbf{z}, \boldsymbol{\beta}) &= \int P(\boldsymbol{\Phi} | \boldsymbol{\beta}) P(\mathbf{w} | \mathbf{z}, \boldsymbol{\Phi}) d\boldsymbol{\Phi}
\end{aligned} \tag{10}$$

위를 이용하여,  $M$ 개의 문서 전체 집합  $\mathcal{C}$ 에 대해 LDA의 marginal probability  $P(\mathbf{W}, \mathbf{Z} | \boldsymbol{\alpha}, \boldsymbol{\beta})$ 을 간결히 정리하시오.

$$P(\mathbf{W}, \mathbf{Z} | \boldsymbol{\alpha}, \boldsymbol{\beta}) = P(\mathbf{Z} | \boldsymbol{\alpha}) P(\mathbf{W} | \mathbf{Z}, \boldsymbol{\alpha}, \boldsymbol{\beta})$$

### 3.2 Conditional probability on topic assignment for Latent Dirichlet Allocation (LDA)

위의 marginal probability  $P(\mathbf{w}, \mathbf{z} | \boldsymbol{\alpha}, \boldsymbol{\beta})$ 로부터 다음의 conditional probability를 유도하시오.

$$P(z_j = i | \mathbf{z}_{-j}, \mathbf{w}, \boldsymbol{\alpha}, \boldsymbol{\beta}) = \frac{P(\mathbf{z}_{-j}, z_j = i, \mathbf{w}, \boldsymbol{\alpha}, \boldsymbol{\beta})}{P(\mathbf{z}_{-j}, \mathbf{w}, \boldsymbol{\alpha}, \boldsymbol{\beta})} \tag{11}$$

여기서  $\mathbf{z}_{-j}$ 는 주어진 문서에서  $j$ 번째 단어를 제외한 다른 모든 단어들에 대한 topic assignment를 의미한다.

위의 하나의 문서에 대한 conditional probability식을 확장하여,  $M$ 개의 문서 전체 집합  $\mathcal{C}$ 에 대한 다음 LDA의 conditional probability  $P(z_{jk} = i | \mathbf{W}, \mathbf{Z}_{-jk}, \boldsymbol{\alpha}, \boldsymbol{\beta})$ 을 간결히 정리하시오.

$$P(z_{jk} = i | \mathbf{Z}_{-jk}, \mathbf{W}, \boldsymbol{\alpha}, \boldsymbol{\beta}) = \frac{P(\mathbf{Z}_{-jk}, z_{jk} = i, \mathbf{W}, \boldsymbol{\alpha}, \boldsymbol{\beta})}{P(\mathbf{Z}_{-jk}, \mathbf{W}, \boldsymbol{\alpha}, \boldsymbol{\beta})} \quad (12)$$

여기서  $\mathbf{Z}_{-jk}$ 는  $j$ 번째 문서의  $k$ 번째 단어를 다른 모든 문서들과 단어들에 대한 topic assignment를 의미한다.

### 3.3 Collapsed Gibbs sampler for Latent Dirichlet Allocation (LDA)

위의 conditional probability를 이용하여 모든 문서에 대해 topic assignment sampling을 수행한 후,  $\boldsymbol{\theta}_j$ ,  $\boldsymbol{\phi}_i$ 를 estimation하는 식을 유도하시오.

이를 이용하여 LDA에 대한 Gibbs sampler 알고리즘을 유도하시오.

### 3.4 Implementation: Gibbs sampling for LDA (python code 제출)

유도된 Gibbs sampler를 python으로 작성하여 LDA 모델에 대한 학습을 수행하고, perplexity를 통해 LDA 모델을 평가하시오.

$q(x) = \text{Cat}(x | \boldsymbol{\theta})$ 가 학습된 Multinoulli 모델이고, 주어진 test 집합  $\mathcal{T}$ 은 총  $M$ 개로 문서들로 구성되며, 이때  $N_{d_i}$ 를 문서  $d_i$ 의 길이,  $w_{ij}$ 가  $i$ 번째 문서의  $j$ 번째 단어라고 할때,  $\mathcal{T}$ 에 대한 model  $q$ 의 perplexity는 다음과 같이 정의된다.

$$\text{perplexity}(q) = \exp \left( -\frac{1}{M} \sum_{i=1}^M \frac{1}{N_{d_i}} \sum_{j=1}^{N_{d_i}} \log q(w_{ij}) \right)$$